

# Usage des bandes hors Tier 1

L. Duflot



# Introduction

- ◆ Un système de bande est un stockage
  - ◆ Possiblement moins coûteux que le disque (dépend des performances attendues)
  - ◆ Probablement moins consommateur d'énergie
- ◆ Le but est de faire une mini revue de l'utilisation “non standard” de bandes, c'est à dire hors du modèle des bandes au Tier 1 comme stockage de grande volumétrie avec stagein/out organisé et à grande bande passante
- ◆ Clairement pas d'application immédiate dans LCG-France pour les sites Tier 2 mais à voir comme une exploration “think outside the box”
- ◆ Je connais deux T2 ayant des bandes : **NET2 (ATLAS – Saul Youssef)** et MIT (CMS – même Data Center NESE ?)
- ◆ BNL a fait une expérimentation de « service HSM » **MÁS (BNLLAKE) (Éric Lançon)**
- ◆ Pour les aspects opérationnels je serai très biaisé ATLAS vu les sites que j'ai contacté et mon expérience perso



# Bandes à NESE



# MGHPCC

Boston University  
Harvard University  
MIT  
Northeastern University  
University of Massachusetts

- 15 megawatt \$90M single purpose data center
- Near zero Carbon footprint
- Space power and cooling for 780 racks
- More than 300,000 x86 cores, millions of gpu cores
- 100Gb/s multi-fiber ring to Boston, NYC and Albany
- Three new top500 in the past year
- Located in Holyoke, MA
- Thousands of researchers in all fields
- 200,000 students; 35% of degrees awarded in MA



Saul Youssef



# NESE Ceph

- 32 PB Ceph
- 80% buy-in
- Rapidly expanding: 167 projects, 162 PIs, 112 organizations
- 9.5 PB raw NESE\_DATADISK, CephFS, 8+3 EC

## NESE Tape(*New*)

- 157 PB capacity IBM TS4500 tape library, 1 PB GPFS cache
  - 110.4 PB buy-in already
  - 50 PB for ATLAS
  - 10 PB for CMS to start...
- Prévoit d'utiliser l'interface xrootd au bande comme pour CTA au CERN
  - Première allocation de 10PB pour ATLAS pour archivage de DAOD
  - Pas d'autre type d'utilisation prévue pour le moment

Saul Youssef



# MÁS at BNL

## BNLLAKE



# MÁS implementation

Highly Used data

More Frequently  
Used Data

Different Hardware  
Retired Storage?

TAPE RSE

DISK RSE

Current disk storage

New RSE

Large Tape Cache

Large Tape Storage



15

Éric Lançon



- ◆ L'idée est d'utiliser le système comme un HSM (mon image) :
  - ◆ Il y a une grande volumétrie sur bande
  - ◆ Un buffer disque, les fichiers peuvent être en permanence sur disque (pinned) ou bien temporairement (évincé selon leur popularité)
  - ◆ Vu comme un système disque de l'extérieur (rucio, ATLAS DDM)
    - ◆ Idéalement serait une QoS intermédiaire entre disque et bande du point de vue de la latence
  - ◆ Implémenté avec dCache QoS
- ◆ Retour d'expérience :
  - ◆ Comme pour le moment rucio / DDM / le job pilot ne sait pas traiter cette QoS intermédiaire, il est difficile de gérer les latences très variables → timeout dans les jobs
  - ◆ Les efforts se concentrent maintenant sur l'implémentation de la QoS dans rucio



# Résumé


- ◆ Utilisation non standard de bandes
  - ◆ NESE data center / NET2 :
    - ◆ librairie en service, bientôt pour ATLAS mais utilisation « habituelle » d'archivage
  - ◆ MÁS à BNL :
    - ◆ Système « transparent de buffer disque devant une librairie »
    - ◆ En l'état actuel difficile à utiliser pour ATLAS, il faut implémenter une QoS dans rucio / DDM
- ◆ Difficile de tirer des leçons pour la France même si un site avait accès à une librairie de bande partagée



# Backup



# Spectrum Archive Architecture ESS



Maximum Capacity: 157 PB  
 9 Frames, expandable to 18  
 28 TS1160 Tape Drives, max 11.2 GB/s  
 ESS-5000: 1.09 PB useable  
 FC and 100Gb networking

IBM GPFS POSIX interface  
 IBM Spectrum Archive Library Software  
 Xrootd with staging  
 Globus 5 with staging  
 S3 via MinIO